

基于改进多层卷积神经网络的水体富营养化遥感监测算法研究

封雷, 封丽, 方芳, 郭劲松, 潘江, 余由, 陈瑜

引用本文

封雷, 封丽, 方芳, 郭劲松, 潘江, 余由, 陈瑜. 基于改进多层卷积神经网络的水体富营养化遥感监测算法研究[J]. 计算机科学, 2022, 49(11A): 210200160-5.

FENG Lei, FENG Li, FANG Fang, GUO Jin-song, PAN Jiang, YU You, CHEN Yu. Improved Water Quality Remote Sensing Monitoring Algorithms Based on Multilayer Convolutional Neural Network [J].

Computer Science, 2022, 49(11A): 210200160-5.

相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于机器学习的剩余使用寿命预测实证研究](#)

Empirical Research on Remaining Useful Life Prediction Based on Machine Learning

计算机科学, 2022, 49(11A): 211100285-9. <https://doi.org/10.11896/jsjcx.211100285>

[基于深度神经网络与联邦学习的污染物浓度预测二次建模](#)

Secondary Modeling of Pollutant Concentration Prediction Based on Deep Neural Networks with Federal Learning

计算机科学, 2022, 49(11A): 211200084-5. <https://doi.org/10.11896/jsjcx.211200084>

[基于差分进化算法的字符对抗验证码生成方法](#)

Adversarial Character CAPTCHA Generation Method Based on Differential Evolution Algorithm

计算机科学, 2022, 49(11A): 211100074-5. <https://doi.org/10.11896/jsjcx.211100074>

[深度神经网络的对抗攻击及防御方法综述](#)

Survey of Adversarial Attacks and Defense Methods for Deep Neural Networks

计算机科学, 2022, 49(11A): 210900163-11. <https://doi.org/10.11896/jsjcx.210900163>

[融合多层次视觉信息的人物交互动作识别](#)

Human-Object Interaction Recognition Integrating Multi-level Visual Features

计算机科学, 2022, 49(11A): 220700012-8. <https://doi.org/10.11896/jsjcx.220700012>

基于改进多层卷积神经网络的水体富营养化遥感监测算法研究

封雷^{1,3} 封丽^{2,4} 方芳¹ 郭劲松¹ 潘江⁵ 余由¹ 陈瑜⁶

1 重庆大学生态与环境学院 重庆 400044

2 重庆市生态环境科学研究院(中国环境科学研究院西南分院) 重庆 401147

3 中国科学院重庆绿色智能技术研究院超分辨光学研究中心 重庆 400714

4 重庆大学材料学院 重庆 400044

5 重庆理工大学化学化工学院 重庆 400054

6 北京生产力促进中心 北京 100088

(fenglei@cigit.ac.cn)

摘要 随着水环境质量监测技术的高速发展,水环境质量数据的种类、数量均都呈现爆炸式增长。原位监测与遥感监测是水环境监测的重要数据来源,如何快速高效地理解海量的监测数据是人工智能技术在生态环境研究领域的热点。因此,以三峡库区境内的国家良好水体——长寿湖为例,研究改进 WRCNN 卷积神经网络算法模型直接对遥感影像中的水环境数据进行特征提取,结合原位在线监测数据对遥感影像数据进行标注,增加 CNN 网络的宽度,提高遥感数据的水环境特征提取的能力,消除函数选择的不确定性,减少参数确定带来的计算步骤和抑制过拟合的影响,实现对大尺度水环境遥感特征的利用。结果表明,改进 WRCNN 卷积神经网络算法模型能有效识别长寿湖富营养化表征指标叶绿素 a 的浓度,为库区水体富营养化监测提供高效手段。

关键词: 神经网络;三峡库区;富营养化;深度学习;遥感监测

中图法分类号 TP181

Improved Water Quality Remote Sensing Monitoring Algorithms Based on Multilayer Convolutional Neural Network

FENG Lei^{1,3}, FENG Li^{2,4}, FANG Fang¹, GUO Jin-song¹, PAN Jiang⁵, YU You¹ and CHEN Yu⁶

1 College of Environment and Ecology, Chongqing University, Chongqing 400044, China

2 Chongqing Academy of Ecological and Environmental Sciences (Southwest Branch of China Academy of Environmental Sciences), Chongqing 401147, China

3 Super Resolution Optics Research Center, Chongqing Institute of Green and Intelligent Technology, Chinese Academy of Sciences, Chongqing 400714, China

4 College of Materials Science and Engineering, Chongqing University, Chongqing 400044, China

5 College of Chemistry and Chemical Engineering, Chongqing University of Technology, Chongqing 400054, China

6 Beijing Productivity Promotion Center, Beijing 100088, China

Abstract With the rapid development of water environment online monitoring technology in recent years, the categories and quantities of monitoring data have been greatly improved. Online monitoring and remote sensing monitoring are important data sources for water environment monitoring. How to quickly and efficiently understand massive monitoring data is a research hotspot of artificial intelligence technology in the field of ecological environment data research. Changshou lake is a national good water body in the Three Gorges reservoir area. This paper aims at proposing an improved CNN convolution neural network algorithm WRCNN model, and this model is studied to extract features directly from water environment data in remote sensing images and increasing data dimension of water monitoring data. The ability of extraction can eliminate the uncertainty of function selection, reduce the calculation steps, suppress the influence of over-fitting and realize the application of remote sensing technology of large-scale monitoring in water environment. The results show that the improved WRCNN convolution neural network algorithm model can effectively identify the concentration of chlorophyll, the indicator of eutrophication in Changshou lake, and provide an efficient measures for monitoring eutrophication in reservoir area.

Keywords Neural network, Three Gorges reservoir, Eutrophication, Deep learning, Remote sensing monitoring

1 引言

水环境质量数据常采用野外原位采样、实验室分析等

方式获取,此类方法针对采样点位的水质反应虽准确度高,但受采样点位的地形限制,每次只能在一个点或者少数监测点上进行分析,且费时、费力、成本高,无法实现大尺度范围

基金项目:重庆市科技攻关项目(应用技术研发类)(环科学 2018 第 04 号, cstc2018jszx-zdyfxmX0020)

This work was supported by the Chongqing Science and Technology Projects (HuanKeZi 2018 No. 04, cstc2018jszx zdyfxmX0020).

通信作者:陈瑜(chenyu_310@126.com)

内的水环境时空变化监测。遥感水质监测技术与水质动态感知监测技术相结合,可以实现大尺度范围内的水环境时空变化监测预警,具有宏观、动态、低成本等优势^[1-2]。卫星遥感影像具有快速成像、大规模、周期性、成本较低的特点^[3-4],可通过遥感影像数据直接定量反演具有显著光谱或光学特性的水质参数,即光活性物质,如叶绿素 a、悬浮物和黄质等,对这些水质参数的实时反演称为水色遥感^[5]。对不具有显著光谱和光学特性的非光活性物质,称为间接水质参数,包括总氮、总磷和营养状况指数,对此类水质参数的遥感反演称为水质遥感^[6-7]。因此,目前遥感水质监测技术研究多集中于水体富营养化监测预警^[8-9]。

卫星遥感影像反演过程即模型求解过程,反演精度取决于传感器本身的性能,包括时间分辨率、空间分辨率、光谱分辨率和辐射分辨率等。模型对水色参数细节光谱特征能力是构建水质遥感反演的核心和关键,构建模型与验证模型是现阶段水质遥感关注的焦点。随着人工智能技术的蓬勃发展,卷积神经网络(Convolutional Neural Network, CNN)模型极大地改善了遥感图像数据的处理^[10-12],对卫星遥感海量数据存储与计算能力需要的特殊数据具有良好的适用性。与传统的统计方法相比,神经网络不需要通过专家经验即可对概率模型做出假设,具有较强的模型自我学习和改进容错能力,适用于遥感影像模式识别问题^[13]。本文提出一种基于改进 CNN 的水环境遥感算法,即一种专门用于遥感图像识别的深度学习技术的多层神经网络,能有效地减少局部感受的训练参数数量和小型遥感样本的权重共享特征^[14-15],池化层可以聚合不同位置的特征,同时对特征进行降维处理,提高拟合精度(不容易过度拟合),也可用于识别遥感影像位移、缩放和其他形式的失真不变性的二维图像。通过对隐函数数据进行训练学习^[16-17],对每一条光谱曲线对应水环境参数影像因子权重映射表征学习,成为 CNN 相比完全连接的神经网络的主要优势^[18-20]。通过 HJ-1/CCD 卫星获取三峡库区龙溪河流域遥感数据,验证了改进 CNN 的水环境遥感算法的精确度,并研发水环境遥感监测系统,以期实现目标水体水环境质量的实时监测预警。

2 基于 CNN 的遥感水环境分析系统设计

2.1 设计目的

基于遥感反演与深度学习技术,结合水环境在线监测时序列的特点, CNN 的遥感水环境分析系统以水环境遥感影像为输入,结合原位在线监测数据,旨在实现三峡库区的大尺度水环境在线遥感水质准确识别诊断,从而为政府机构、环境专家、相关从业者提供一种可靠、易用的大尺度水环境监测和辅助决策工具。

2.2 功能设计

根据水环境遥感监测智慧系统的设计要求,采用模块化的思想进行系统功能设计,将系统功能划分为遥感数据处理模块、水环境智能分析模块、数据管理模块、系统管理模块和虚拟化展示模块,如图 1 所示。由图 1 可知,水环境遥感监测系统中遥感数据处理模块的主要功能是对遥感数据进行预处理,实现对遥感数据的校对、云掩模、噪声消除等操作。水环境智能分析模块是基于人工算法构建遥感数据和原位监测数据相耦合的水环境智能分析模型,实现水质状况预测、遥感自动反演、环境综合评价、水环境数据同化融合等功能。系统

管理模块主要包含日志管理、中间件管理、权限管理、用户信息管理等功能。虚拟化展示模块主要结合地理信息数据和遥感水环境监测数据实现对水环境的数据和分析进行在线展示。

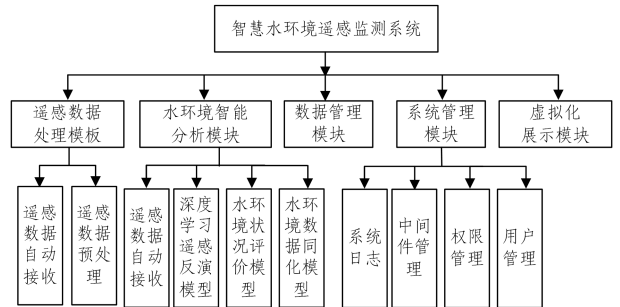


图 1 水环境遥感卷积神经网络分析系统整体功能

Fig. 1 Structure of remote sensing water environment analysis system based on convolutional neural network

3 遥感数据处理模型构建

3.1 遥感数据预处理

不同类型的水环境问题,如不同类型的河流湖泊水体富营养化,其光谱也有不同的特点。基于遥感影像的水环境识别的关键是频谱的特征提取和映射模型优化。由于重庆地处三峡库区,地势特殊,遥感影像包含大量的复杂背景和云噪声。如果遥感图像直接被用作水环境识别分类器的输入,则分类器难以准确地获取由噪声干扰引起的光谱特征,准确性很低。因此,消除传输过程中由大气散射和吸收引起的辐射误差的过程称为遥感数据的大气校正。

在前期对遥感数据进行预处理可采用大气校正模型 FLAASH。FLAASH 是反演的首选大气校正模型,其适用的波长范围包括可见光至近红外和短波红外,最大波长范围为 $3\mu\text{m}$,可精确补偿大气校正带来的影像。其他大气校正模型基于查找表计算并通过插值法计算,FLAASH 模型直接移植到 Modtran4 的辐射传输计算方法中。FLAASH 大气校正算法的主要输入参数包括图像中心位置、成像时间、传感器类型、地面平均高度、地理高层、图像空间分辨率、气溶胶模型、使用的大气模型、水汽特征带、大气能见度、气溶胶参数提取方法,以及是否执行光谱平滑和波长重新校正等。

3.2 评价模型构建

对于水环境质量的测定,主要指标有 BOD_5 、COD、DO 等。水体富营养化主要涉及叶绿素浓度。 BOD_5 代表生化需氧量,即需氧微生物在有氧条件下每单位体积水中有机物分解所消耗的游离氧量。污水中有机物的成分复杂,难以直接测量各种有机物的绝对含量,生化需氧量常用于间接指示有机物含量。COD 代表化学需氧量,是化学氧化剂氧化单位体积水所消耗氧的量。由于氧化剂氧化有机物质时,一些还原性无机物质,如亚硝酸盐、硫化物或亚铁盐等,也会被氧化,因此它不能像 BOD_5 那样表示微生物氧化的有机物质的量。光谱分析实验表明, BOD_5 与 737nm 和 528nm 的反射率具有良好的相关性,COD 浓度与 728nm 和 523nm 的反射率具有良好的相关性。水体富营养化监测可以基于 CCD 数据建立基于叶绿素和藻类含量的决策树模型,以提取水华信息。通过构建近红外和可见光带的比例,实现水华的特征信息提取,其精度超过了原始的水华视觉分析和提取方法,同时应用范围更广。

遥感技术已成为监测水体空间和时间分布的重要方法。在研究遥感模型构建时利用空间分辨率和时间分辨率都较高的 HJ-1/CCD 数据监测水体富营养化的遥感图像数据,取得了良好的效果。这些反演模型能够快速寻找对水体富营养化变化最敏感的光谱因子或光谱因子组合,同时还能减小水中其他参数因子对结果的影响。

3.3 反演模型构建

遥感技术已经成为监测水体水质状况时空分布的重要方式。该研究方案通过构建遥感富营养化水体监测模型,选取对应遥感影像数据空间分辨率、时间分辨率都较高的 HJ-1/CCD 数据,通过与人工采样结果对比取得了不错的效果。其遥感反演估算模型旨在寻找对富营养化水体状态变化最为敏感的光谱因子或光谱因子组合,同时还要减小水中其他组分对不同光谱数据的影响。

对于富营养化污染水体,其主要遥感监测指标是叶绿素、COD 浓度等,对于遥感反演,选取对光反射率有良好相关性的叶绿素等指标。光谱分析实验表明,Chla 与 735 nm 和 575nm 的反射率具有良好的相关性,COD 浓度与 728 nm 和 523 nm 的反射率具有良好的相关性。

在建立库区富营养化遥感影像的多层卷积深度学习模型之前,参考前期研究成果,使用波段或波段组合对水体富营养状态进行反演分析。通过对富营养化指数的相关因子进行相关分析,并建立回归方程。之后通过多参数构建 Tensor 张量模型,并以此数据为基础构造卷积神经网络模型,建立遥感反演光谱之间的关系模型。

通过对富营养化遥感光谱反演,发现叶绿素 a 与水体富营养状态的相关性最大,其叶绿素反射峰与吸收峰之间的差异能够有效地体现富营养状态的光谱数值信息,同时达到提取叶绿素 a 的目的。通过对比分析水体富营养状态特征光谱和环境一号卫星 CCD 相机的波段设置,对不同特征波段组合的反射率与实测的叶绿素 a 浓度值进行相关性分析,式(1)~式(3)列出了 R^2 大于 0.8 的 3 种波段组合及对应的回归关系,分别选取这 3 种波段组合所有回归关系中 R^2 最大的进行建模。

$$Chla = a \times R_n(CCD4) / R_n(CCD3) + b \quad (1)$$

$$Chla = c \times [R_n(CCD3)^{-1} - R_n(CCD4)^{-1}] \times R_n(CCD4) + d \quad (2)$$

$$Chla = e \times [R_n(CCD3)^{-1} - R_n(CCD4)^{-1}] / [R_n(CCD4)^{-1} + R_n(CCD3)^{-1}] + f \quad (3)$$

其中,Chla 为叶绿素 a 的浓度,且 a, b, c, d, e, f 是最佳拟合系数。

为获取叶绿素 a 状态遥感最优反演模型,将环境一号卫星 CCD 影像的上述 3 种波段组合的 18 个验证样本反射率分别应用到对应模型中进行叶绿素 a 浓度反演;使用均方根误差(RMSE)作为检验叶绿素 a 反演值和实测值是否可信的评价标准,表达式如下:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_{mod,i} - x_{obs,i})^2}{n}} \quad (4)$$

其中, x_{mod} 表示通过遥感数据计算的叶绿素 a 浓度的反演值, x_{obs} 表示叶绿素 a 浓度的实测值, n 为检验样本数 18, 平均相对误差是对每个计算结果误差取绝对值后的平均。

综合各项指标可认为式(3)是上述三者中的最优模型(见图 2)。将 18 个检验样本用于该模型,获得叶绿素 a 浓度反演

值,通过与实测值进行比较, R^2 达到 0.835, 总体反演效果良好(见图 3)。




图 2 叶绿素 a 最优反演模型

Fig. 2 Optimal inversion model of chlorophyll a




图 3 叶绿素 a 反演值与实测值间的相关性分析

Fig. 3 Correlation analysis between inversion value and measured value of chlorophyll a

3.4 基于多层卷积神经网络的水质遥感(WRCNN)模型构建

WRCNN 是基于 CNN 构建的一个多层的神经网络,由输入层、特征提取层以及分类器组成,每层由多个矩阵相互独立神经元组成。网络通过逐层的特征提取学习输入遥感影像的高层特征,然后将其输入到分类器中对结果进行识别。图 4 给出了通过三峡库区长寿湖地区的遥感数据构建 WRCNN 多层卷积神经网络分析模型。




图 4 基于多层卷积神经网络的长寿湖遥感反演模型

Fig. 4 Remote sensing inversion model of Changshou lake based on WRCNN multilayer convolutional neural network

卷积层是多层卷积神经网络的特征映射层,具有局部连接和权值共享的特征。该种特征降低了神经网络模型的复杂度,使需要调整的参数数量减少。池化层是卷积神经网络的特征提取层,它将输入中连续范围作为池化区域,并且只对重复的隐变量单元输出特征进行池化,该操作使卷积神经网络具有平移不变性。在对遥感影像进行训练时,实际上因为遥感样本量不足,因此在每个训练批次中需要忽略一半的特征检测器(让一半的隐层节点值为 0),这样可以明显地减少过拟合现象。这种方式可以减少水环境遥感训练特征检测器(隐层节点)间的相互作用。在前向传播时,让某个神经元以一定的概率 p 停止工作,这样可以使模型泛化性更强,因为不会太依赖某些局部的特征。其操作步骤如下:

(1)首先构建随机算法删掉深度学习网络中一半的隐藏神经元,输入输出神经元保持不变(图 5 中虚线为部分临时被删除的神经元)。

(2)其次把输入的遥感光谱数据通过修改后的网络向前

传播,之后把得到的损失结果通过修改之后的网络反向传播。训练样本执行完这个过程后,更新对应的参数。

(3)然后继续重复 1,2 步骤,恢复之前删除的神经元。从隐藏层神经元中随机选择部分子集数据临时删除掉。

(4)最后通过遥感光谱数据结合水质原位在线监测样本数据,不断重复这一过程,最终使遥感影像数据得到充分训练,其 WRCNN 多层卷积神经网络公式如下:

$$\min_{U,V,d} \mathbb{E}_r \| X - \frac{1}{\theta} U \text{diag}(r) V^T \|^2 = \min_{U,V,d} [\| X - UV^T \|^2_F + \frac{1-\theta}{\theta} \sum_{k=1}^d \| u_k \|^2 \| v_k \|^2] \quad (5)$$




图 5 被删掉的网络中的隐藏神经元

Fig. 5 Hidden neurons in deleted network

4 实验结果

4.1 数据选取

实验数据取自 HJ-1A/B 卫星,该卫星于 2008 年 9 成功发射,在两颗卫星上装载的两台 CCD 相机,可生成 4 个谱段的推扫成像,其对地幅宽度为 700 km、地面像元分辨率为 30m,两台 CCD 相机组网后重访周期为 2 d,其过境长寿湖的时间约为上午 10:00-11:00。由于三峡库区实际上存在较强的持续云遮挡,选取了 2015 年 3 月到 2018 年 10 月的 157 幅遥感影像中的实地采样区域(湖区面积 66 km²),其环境 1 号星 CCD 遥感影像如图 6 所示。




图 6 HJ-1A/B 类遥感图像场景示例

Fig. 6 Example of HJ-1A/B remote sensing image scene

4.2 图像处理

在用 WRCNN 算法对图像进行训练前,先对遥感光谱数据进行归一化处理,将其映射到输出层的激活函数值域(0,1)区间内。由于遥感训练数据的特殊性,本文方法对归一化后的遥感数据进行一系列的随机反向训练来增加模型数据样本量。每次训练时会生成多个随机光谱数据,直到达到规定的 epoch 次数为止。每个 epoch 将生成一个批次的遥感数据。实时数据提升的图像经过随机概率变换预处理后有利于抑制

过拟合,提高模型的泛化能力。实验过程中随机选取总数据的 80% 的遥感影像数据作为训练数据,其余 20% 为测试数据。

4.3 实现对比分析

为分析本文中所采用的针对遥感影像数据的改进的 WRCNN 方法与传统 CNN 方法和 Inception 方法之间的差异,在同样的数据集三峡库区长寿湖遥感影像上进行分类实验。图 7 给出了这 3 种方法随训练的次增加收敛情况的变化。由实验可知,WRCNN 模型在大部分的情况下能够收敛更快,精度更好。




图 7 不同算法间的 MAE 变化比较

Fig. 7 Comparison of MAE changes between different algorithms

4.4 实验结果及分析

首先利用 WRCNN 模型从原始遥感影像中提取水面光谱数据特征,并在通过原位监测数据进行验证,该特性使 WRCNN 更擅长识别遥感影像数据的水体信息。为展示 WRCNN 对遥感影像数据处理的情况,图 8 给出了一张在 2018 年不同时期长寿湖水体叶绿素含量变化情况的遥感影像。由图可见,在对遥感影像进行卷积层卷积处理后所呈现的数据可以更加清晰直观地展示。图中 4 月份水体叶绿素浓度开始升高,在 7 月份达到顶峰,这与实测结果相吻合。因此经过反复试验和对比,基于 WRCNN 的水环境遥感卷积神经网络模型可以对遥感信息进行比较准确地提取,基本可以实现水质状态自动反演的要求。

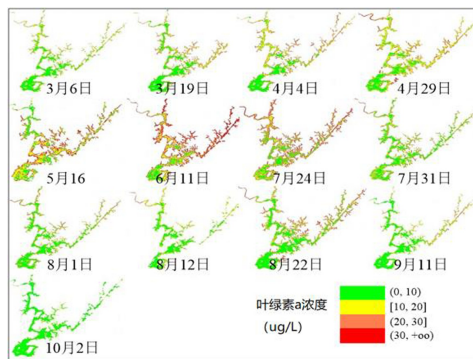


图 8 长寿湖地区叶绿素 a 自动反演结果分布图

Fig. 8 Distribution of chlorophyll a inversion results in Changshou lake area based on WRCNN algorithm

4.5 系统实现

图 9 给出了对本文中 WRCNN 方法的系统实现,系统采用收集的数据集和构建 GIS 引擎来实现遥感水环境的自动反演识别。提取遥感数据水体辐射反射特征,如蓝波段、近红外、彩虹外以及不同波段的比值指数、归一化区分指数、空间特征等,利用地面监测数据与遥感影像进行原位监测,对边构建基于遥感影像数据与原位监测数据的遥感水质卷积神经网络模型,以监测水质变化。




图9 基于深度学习技术的遥感自动反演监测系统实现
Fig.9 Implement of remote sensing automatic inversion monitoring system based on WRCNN algorithm

结束语 本文通过研究一种改进 WRCNN 卷积神经网络算法模型直接对遥感影像中的水环境数据进行特征提取,通过结合原位在线监测数据对遥感影像数据进行标注,增加 CNN 网络的宽度,从而提高遥感数据的水环境特征提取的能力,实现对大尺度水环境遥感特征的利用,从而可消除函数选择的不确定性,减少参数确定带来的计算步骤和抑制过拟合的影响。实验结果表明,本文算法在三峡库区长寿湖水体上取得了较好的识别效果。下一步将在优化上述模型的基础上,针对总磷、总氮等水体污染物质的高精度遥感反演问题开展重点研究,进一步优化 WRCNN 模型在背景干扰条件下的低误差识别等问题。

参考文献

- [1] ZOU J Y. Research on water quality monitoring system based on ZigBee and Labview technology [D]. Hangzhou: China University of Metrology, 2016.
- [2] GRIFFITH J F, WEISBERG S B, SOBIN J M. Challenges in Implementing New Technology for Beach Water Quality Monitoring; Lessons From a California Demonstration Project[J]. Marine Technology Society Journal, 2011, 45(2): 65-73.
- [3] CUI Y, ZHU G W, ZHANG Y L, et al. Research on high-frequency monitoring method for lake and reservoir eutrophication indicators Research [J]. Journal of Environmental Science, 2014, 34(5): 1178-1185.
- [4] TRESKOTT A, PARK M H. Remote sensing models using Landsat satellite data to monitor algal blooms in Lake Champlain[J]. Water Science & Technology, 2013, 67(5): 1113-1120.
- [5] WU H, YE L P, SHI W Z, et al. Assessing the effects of land use spatial structure on urban heat islands using HJ-1B remote sensing imagery in Wuhan, China[J]. International Journal of Applied Earth Observation and Geoinformation, 2014, 32: 67-68.
- [6] LI Y P, HUA L, TAN Y F, et al Simulation of water transparency in shallow lakes based on bio optical model [J]. Journal of Hydropower, 2013, 32(6): 8.
- [7] PAN Z, HU Y, CAO B. Construction of smooth daily remote sensing time series data: a higher spatiotemporal resolution perspective [J]. Open Geospatial Data, Software and Standards, 2017, 2(1): 25.
- [8] HE L Y, YING G G, LIU Y S, et al. Discharge of swine wastes risks water quality and food safety: Antibiotics and antibiotic resistance genes from swine sources to the receiving environments [J]. Environment International, 2016, 92/93: 210-219.
- [9] BOWES M J, LOEWENTHAL M, READ D S, et al. Identifying multiple stressor controls on phytoplankton dynamics in the

River Thames(UK) using high-frequency water quality data [J]. Science of the Total Environment, 2016: 569/570: 1489-1499.

- [10] KAI Z, ZUO W, GU S, et al. Learning Deep CNN Denoiser Prior for Image Restoration[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 2808-2817.
- [11] JOURABLOO A, LIU X. Pose-Invariant Face Alignment via CNN-Based Dense 3D Model Fitting[J]. International Journal of Computer Vision, 2017, 124(2): 187-203.
- [12] BLOM H A. Indirect measurement of key water quality parameters in sewage treatment plants[J]. Journal of Chemometrics, 1996, 10(5/6): 697-706.
- [13] YUN R, CHANGREN Z, SHUNPING X. Small Object Detection in Optical Remote Sensing Images via Modified Faster R-CNN[J]. Applied Sciences, 2018, 8(5): 813.
- [14] SHEN T, ZHOU T, LONG G, et al. DiSAN: Directional Self-Attention Network for RNN/CNN-free Language Understanding[C]//National Conference on Artificial Intelligence. Association for the Advancement of Artificial Intelligence (AAAI), 2018: 2377-2380.
- [15] CAO R, ZHANG Q, ZHU J, et al. Enhancing Remote Sensing Image Retrieval with Triplet Deep Metric Learning Network [J]. International Journal of Remote Sensing, 2020, 41(2): 740-751.
- [16] CHAIB S, YAO H, GU Y, et al. Deep feature extraction and combination for remote sensing image classification based on pre-trained CNN models[C]//Ninth International Conference on Digital Image Processing(ICDIP 2017). 2017.
- [17] NOOTHOUT J M H, DE V B D, WOLTERINK J M, et al. CNN-based Landmark Detection in Cardiac CTA Scans[J]. arXiv:1804.04963, 2018.
- [18] LIU T, DONG A, XU W, et al. Study on extracting reflectance just beneath water surface from remote sensing reflectance [C]//Geoinformatics. International Society for Optics and Photonics, 2007.
- [19] RAYCHAUDHURI B, ROY S. Martian Atmospheric Spectral Radiance Used as Model for Water Vapor Correction of Terrestrial Carbon Dioxide Absorption Profile Around $2\mu\text{m}$ [J]. IEEE Geoscience and Remote Sensing Letters, 2021: 18-10.
- [20] WANG J, YANG C, SUN C. A Novel Algorithm for Edge Detection of Remote Sensing Image Based on CNN and PSO[C]//2009 2nd International Congress on Image and Signal Processing. IEEE, 2009.



FENG Lei, born in 1990, Ph.D. His main research interests include environmental information and environmental remote sensing research.



CHEN Yu, born in 1990, assistant researcher. Her main research interests include deep learning modeling and so on.